

**SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET**

ZAVRŠNI RAD

**ANALIZA MODELA ZA PREDVIĐANJE
FINANCIJSKE NESTABILNOSTI
PROIZVODNIH PODUZEĆA U RH**

Mentor:

doc. dr. sc. Slavko Šodan

Student:

Slavica Markić

Split, srpanj, 2016.

SADRŽAJ

1. UVOD	4
2. REGULATORNI OKVIR ZA FINANCIJSKO IZVJEŠTAVANJE I TEMELJNI FINANCIJSKI IZVJEŠTAJ	5
2.1. Regulatorni okvir za financijsko izvještavanje u RH	5
2.2. Temeljni financijski izvještaji	7
2.2.1. Bilanca.....	8
2.2.2. Račun dobiti i gubitka	9
2.2.3. Izvještaj o ostaloj sveobuhvatnoj dobiti	11
2.2.4. Izvještaj o novčanim tokovima	11
2.2.5. Izvještaj o promjenama kapitala.....	12
2.2.6. Bilješke uz financijske izvještaje	12
3. TEORIJSKI OSVRT NA PROGNOСТИČKE MODELE PREDVIĐANJA FINANCIJSKIH NESTABILNOSTI.....	13
3.1. Altmanov Z-score model	13
3.2. Kralicekov DF pokazatelj	15
3.3. Zmijewski model	16
3.4. Springate model	17
3.5. BEX indeks	17
4. ANALIZA MODELA ZA PREDVIĐANJE FINANCIJSKE NESTABILNOSTI NA PRIMJERU PROIZVODNIH PODUZEĆA U RH	20
4.1. Izračun modela za predviđanje financijske nestabilnosti za poduzeće Chromos Ago d.d.....	20
4.1.1. Opći podaci o poslovanju Chromos Agro d.d.	20
4.1.2. Izračun Altman Z- score modela	21
4.1.3. Izračun Kralicekovog DF pokazatelja.....	22
4.1.4. Izračun Zmijewskog modela	23
4.1.5. Izračun Springate modela	24
4.1.6. Izračun BEX indeksa.....	25
4.2. Izračun modela za predviđanje financijske nestabilnosti za poduzeće Petrokemija d.d.....	26
4.2.1. Opći podaci o poslovanju poduzeća Petrokemija d.d.	27
4.2.2. Izračun Altman Z-score modela	27
4.2.3. Izračun Kralicekovog DF pokazatelja.....	28
4.2.4. Izračun Zmijewskog modela	29

4.2.5.	Izračun Springate modela	30
4.2.6.	Izračun BEX indeksa	31
4.3.	Izračun modela za predviđanje financijske nestabilnosti za poduzeće Saponia d.d.	32
4.3.1.	Opći podaci o poslovanju poduzeća Saponia d.d.	32
4.3.2.	Izračun Altman Z – score modela	33
4.3.3.	Izračun Kralicekovog DF pokazatelja	34
4.3.4.	Izračun Zmijewskog modela	35
4.3.5.	Izračun Springate modela	36
4.3.6.	Izračun BEX indeksa	37
4.4.	Izračun modela za predviđanje financijske nestabilnosti za poduzeće TOZ Penkala d.d.	38
4.4.1.	Opći podaci o poslovanju poduzeća TOZ Penkala d.d.	38
4.4.2.	Izračun Altman Z- score modela	39
4.4.3.	Izračun Kralicekovog DF pokazatelja	40
4.4.4.	Izračun Zmijewskog modela	40
4.4.5.	Izračun Springate modela	42
4.4.6.	Izračun BEX indeksa	43
4.5.	Sinteza rezultata i ocjena validnosti modela za predviđanje financijske nestabilnosti	44
5.	ZAKLJUČAK	46
	LITERATURA	47
	POPIS TABLICA	49
	POPIS SLIKA	50
	SAŽETAK	51
	SUMMARY	51

1. UVOD

Postoje brojni modeli koji se bave predviđanjem i koji nastoje predviđati financijske nestabilnosti poduzeća. Upravo ti modeli mogu pružiti korisne informacije o financijskoj situaciji poduzeća zainteresiranim korisnicima poput investitora, kreditora, zaposlenika. Iste te informacije mogu biti korisne i za poduzeća koja se mogu suočiti za eventualnim poteškoćama i izbjeći eventualni rizik. Većina postojećih modela koja se bave predviđanjem financijske nestabilnosti bazirana su na informacijama iz financijskih izvještaja. Zbog kompleksnosti okoline brojni istraživači i znanstvenici s vremenom su nadopunjavali modele različitim varijablama u nastojanju da se dobiju što precizniji modeli koji će davati kvalitetnije i pouzdanije ocjene.

U izrazito kompleksnoj okolini nalaze se proizvodna poduzeća koja su u stanju stalnog pritiska na prilagođavanje novim tržišnim uvjetima, povećanjima učinkovitosti i snižavanju troškova. Zbog dinamike u okruženju i poslovanju proizvodna poduzeća se suočavaju sa brojnim financijskim nestabilnostima koja se mogu predvidjeti pravovremenom upotrebom prognostičkih modela i na taj način pokušati spasiti poduzeće od eventualnog stečaja.

Cilj rada je ispitati validnost prognostičkih modela na temelju podataka iz financijskih izvještaja poduzeća u djelatnosti proizvodnje kemikalija i kemijskih proizvoda (Chromos Agro d.d., Petrokemija d.d., Saponia d.d. i Tvornica olovaka Zagreb) za razdoblje od 2011. do 2014. godine, kako bi se utvrdilo koji od sljedećih modela najtočnije i najranije predviđa stečaj poduzeća. Od prethodno navedena četiri poduzeća, poduzeće Tvornica olovaka Zagreb je u stečaju od 2015. godine, dok je za poduzeće Petrokemija d.d. pokrenuta predstečajna nagodba. Na temelju ovih poduzeća se može provjeriti koliko godina unazad prognostički modeli prognoziraju stečaj, odnosno koji prognostički model najranije ukazuje na stečaj. Prognostički modeli koji će se koristiti u radu su: Altamnov Z score model, Kralicekov DF pokazatelj, Zmijewski model, Springate model i BEX indeks, koji će u nastavku biti detaljno objašnjeni.

Završni rad je podijeljen u pet glavnih cjelina. Nakon uvodnog dijela u kojem je izložen problem istraživanja i cilj rada, u drugom dijelu će se detaljnije objasniti zakonska regulativa u RH i teorijski obraditi temeljni financijski izvještaji. U trećem dijelu će se navesti i teorijski obraditi modeli za predviđanje financijske nestabilnosti, koji će se u četvrtom dijelu primijeniti na primjerima poduzeća u djelatnosti proizvodnje kemikalija i kemijskih proizvoda u RH. U zaključnom dijelu ukratko će se sažeti glavni rezultati rada.

2. REGULATORNI OKVIR ZA FINANCIJSKO IZVJEŠTAVANJE I TEMELJNI FINANCIJSKI IZVJEŠTAJ

U Republici Hrvatskoj za financijsko izvještavanje nadležan je Zakon o računovodstvu. Njime se uređuje računovodstvo poduzetnika, primjena standarda financijskog izvještavanja, primjena knjigovodstvenih isprava i poslovnih knjiga, izrada godišnjih financijskih izvještaja i konsolidacija, javna objava godišnjih financijskih izvještaja, razvrstavanje poduzetnika, revizija i sadržaj godišnjih financijskih izvještaja. U prvom djelu će se detaljnije objasniti regulatorni okvir financijskog izvještavanja, te primjena aktualnih zakona i standarda u sastavljanju i objavi godišnjih financijskih izvještaja. U drugom djelu će se teoretski obraditi temeljni financijski izvještaji koje je prema Zakonu o računovodstvu poduzetnik dužan sastavljati i javno objavljivati.

2.1. Regulatorni okvir za financijsko izvještavanje u RH

Mikro, mali i srednji poduzetnici su dužni primjenjivati Hrvatske standarde financijskog izvještavanja prilikom sastavljanja i prezentiranja godišnjih financijskih izvještaja, dok veliki poduzetnici i oni čije dionice ili dužnički vrijednosni papiri su uvršteni ili se obavlja priprema za njihovo uvrštenje na organizirano tržište vrijednosnih papira primjenjuju Međunarodne standarde financijskog izvještavanja prilikom sastavljanja i prezentiranja godišnjih financijskih izvještaja.¹

Hrvatski standardi financijskog izvještavanja su računovodstvena načela i pravila priznavanja, mjerenja i klasifikacije poslovnih događaja te sastavljanja i prezentiranja financijskih izvještaja koje donosi Odbor za standarde financijskog izvještavanja u skladu s ovim Zakonom i objavljuju se u Narodnim novinama.² Međunarodni standardi financijskog izvještavanja su međunarodni računovodstveno standardi uređeni člankom 2. Uredbe (EZ) br. 1606/2002.

Poduzetnici su: ³

1. trgovačko društvo i trgovac pojedinac određeni propisima kojima se uređuju trgovačka društva,
2. poslovne jedinice poduzetnika koje imaju sjedište u drugim zemljama članicama,
3. poslovne jedinice sa sjedištem u trećoj državi u kojoj postoji obveza vođenja poslovnih knjiga i sastavljanja/objavljivanja financijskih izvještaja,

¹ Zakon o računovodstvu, pročišćeni tekst (NN 78/15, 134/15), čl. 17.

² Ibidem, čl. 16.

³ Ibidem, čl. 4.

4. podružnica inozemnih poduzetnika u Republici Hrvatskoj, ako ista nije poslovna jedinica.

Poduzetnici se razvrstavaju na mikro, male, srednje i velike ovisno o pokazateljima utvrđenim na zadnji dan poslovne godine koja prethodi godini za koju se sastavljaju financijski izvještaji.

Pokazatelji na osnovu kojih se razvrstavaju poduzetnici su:⁴

1. iznos ukupne aktive,
2. iznos prihoda,
3. prosječni broj radnika tijekom poslovne godine.

U Tablici 1 su prikazani pokazatelji za razvrstavanje poduzeća na mikro, male, srednje i velike poduzetnike.

Tablica 1: Pokazatelji za razvrstavanje poduzeća prema Zakonu o računovodstvu

Veličina poduzeća	Pokazatelji	
Mikro poduzetnici (oni koji ne prelaze dva od tri navedena pokazatelja)	Ukupna aktiva	< 2.600.000,00 kn
	Ukupan prihod	< 5.200.000,00 kn
	Broj zaposlenih	< 10
Mali poduzetnici (koji ne prelaze dva od tri navedena pokazatelja)	Ukupna aktiva	< 30.000.000,00 kn
	Ukupan prihod	< 60.000.000,00 kn
	Broj zaposlenih	< 50
Srednji poduzetnici (koji ne prelaze dva od tri navedena pokazatelja)	Ukupna aktiva	< 150.000.000,00 kn
	Ukupan prihod	< 300.000.000,00 kn
	Broj zaposlenih	< 250
Veliki poduzetnici (koji prelaze pokazatelje u najmanje dva od tri uvjeta za srednja poduzeća)		

Izvor: Zakon o računovodstvu, pročišćeni tekst (NN 78/15, 134/15), čl. 5.

Ostali veliki poduzetnici su: banke, štedne banke, stambene štedionice, institucije za elektronički novac, društva za osiguranje, društva za reosiguranje, leasing- društva, mirovinska društva koja upravljaju obveznim mirovinskim fondovima, mirovinska društva koja upravljaju dobrovoljnim mirovinskim fondovima, faktoring-društva, investicijska društva, burze i itd.⁵

⁴ Zakon o računovodstvu, op.cit., čl. 5.

⁵ Zakon o računovodstvu, op.cit., čl. 5.

Poduzetnici su dužni sastavljati godišnje financijske izvještaje. Godišnje financijske izvještaje čine:⁶

1. Izvještaj o financijskom položaju (bilanca)
2. Račun dobiti i gubitka
3. Izvještaj o ostaloj sveobuhvatnoj dobiti
4. Izvještaj o novčanim tijekovima
5. Izvještaj o promjenama kapitala
6. Bilješke uz financijske izvještaje.

Iznimno, mali i mikro poduzetnici sastavljaju bilancu, račun dobiti i gubitka i bilješke uz financijske izvještaje. Poduzetnici koji su prema Zakonu o računovodstvu obveznici sastavljanja godišnjih izvješća, dužni su ih dostaviti Financijskoj agenciji radi javne objave.

2.2. Temeljni financijski izvještaji

Cilj financijskog izvještavanja je informiranje zainteresiranih korisnika o financijskom položaju kao i uspješnosti poslovanja. Informirati korisnike znači prezentirati im sve relevantne i istovremeno pouzdane računovodstvene informacije u obliku i sadržaju prepoznatljivom i razumljivom osobama kojima su namijenjene. Te su informacije sadržane u nizu financijskih izvještaja.⁷ Temeljni financijski izvještaji prvenstveno su namijenjeni vanjskim korisnicima poduzeća, no oni daju informacije i unutarnjim korisnicima. Temeljni financijski izvještaji trebaju fer i istinito prezentirati financijski položaj, financijsku uspješnost i novčane tokove poduzetnika. Fer prezentacija zahtjeva vjerno predočavanje učinaka transakcija i drugih događaja, a u skladu kriterijima priznavanja imovine, obveza, kapitala, prihoda i rashoda.⁸

Temeljni financijski izvještaji u Republici Hrvatskoj su:⁹

1. Bilanca,
2. Račun dobiti i gubitka,
3. Izvještaj o ostaloj sveobuhvatnoj dobiti,
4. Izvještaj o novčanim tokovima,
5. Izvještaj o promjenama kapitala,

⁶ Zakon o računovodstvu, op.cit., čl. 19.

⁷ Žager K., Žager L. (1999): Analiza financijskih izvještaja, Masmedia, Zagreb, str. 33.

⁸ Skupina autora (2008): Primjena hrvatskih standarda financijskog izvještavanja, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb, str 35.

⁹ Zakon o računovodstvu, op.cit., čl. 19.

6. Bilješke uz financijske izvještaje.

2.2.1. Bilanca

Jedan od temeljnih financijskih izvještaja je bilanca. Bilanca je sustavni pregled imovine, kapitala i obveza gospodarskog subjekta na određeni datum, najčešće na datum završetka fiskalne godine.¹⁰ Bilanca pruža informacije o financijskoj snazi poduzeća, likvidnosti, mogućnosti podmirivanja kratkoročnih obveza, horizontalnoj financijskoj strukturi, položaju poduzeća u odnosu na druga poduzeća iz sličnih djelatnosti te je osnovna podloga za analizu financijskog položaja i financijske stabilnosti.¹¹

Bilanca se sastoji od dva dijela, aktive i pasive. Aktiva prikazuje imovinu s kojom poduzeće raspolaže, dok pasiva prikazuje izvore imovine. Aktiva je uvijek jednaka pasivi, tj. imovina je jednaka zbroju kapitala i obveza. Aktiva bilance dijeli se na dvije osnovne skupine imovine: dugotrajnu (stalna imovina) i kratkotrajnu imovinu (tekuća ili obrtna imovina).

Kratkotrajna imovina je onaj dio ukupne imovine za koji se očekuje da će se pretvoriti u novčani oblik u razdoblju kraćem od jedne godine. Kratkotrajna imovina se sastoji od:¹²

1. Novac (u banci i u blagajni)
2. Potraživanja (od kupaca, od zaposlenih, ostala potraživanja)
3. Financijska imovina (dani kratkoročni krediti, kupljeni vrijednosni papiri, ostala kratkotrajna ulaganja)
4. Zalihe (sirovina i materijala, proizvodnje, gotovih proizvoda, trgovačke robe)

Dugotrajna imovina je onaj dio ukupne imovine poduzeća koji duže ostaje vezan u postojećem obliku i koji se postepeno pretvara u novac u toku više obračunskih razdoblja tj. u razdoblju dužem od godine dana.¹³

Dugotrajna imovina može biti:¹⁴

1. Materijalna (zemljišta, zgrade, postrojenja i oprema, alati, uredski inventar)
2. Nematerijalna (patenti, licencije, koncesije, goodwill, istraživanje i razvoj)
3. Financijska (dani krediti, depoziti i kaucije, vrijednosni papiri)

¹⁰ Vidučić Lj. (2006): Financijski menadžment, RRiF – plus, d.o.o. za nakladništvo i poslovne usluge, Zagreb, str. 366.

¹¹ Šodan S.: Financijska analiza poslovanja, skripta, Split, ak.god. 2014./2015. predavanja br. 4 i 5, str. 2.

¹² Žager K., Žager L. (2008): Analiza financijskih izvještaja, Masmedia, Zagreb, str. 56.

¹³ Ibidem, str. 57.

¹⁴ Ibidem

4. Potraživanja (prodaja na kredit, ostala potraživanja)

U Tablici 2 su prikazane temeljne pozicije bilance.

Tablica 2: Temeljne pozicije bilance - obrazac GFI - POD

Aktiva	Pasiva
A. Potraživanja za upisani a neuplaćeni kapital	A. Kapital i rezerve
B. Dugotrajna imovina	<i>I. Temeljni (upisani) kapital</i>
<i>I. Nematerijalna imovina</i>	<i>II. Kapitalne rezerve</i>
<i>II. Materijalna imovina</i>	<i>III. Rezerve iz dobiti</i>
<i>III. Dugotrajna financijska imovina</i>	<i>IV. Revalorizacijske rezerve</i>
<i>IV. Potraživanja</i>	<i>V. Zadržana dobit ili preneseni gubitak</i>
<i>V. Odgođena porezna imovina</i>	<i>VI. Dobit ili gubitak tekuće godine</i>
C. Kratkotrajna imovina	<i>VII. Manjinski interes</i>
<i>I. Zalihe</i>	B. Rezerviranja
<i>II. Potraživanja</i>	C. Dugoročne obveze
<i>III. Kratkotrajna financijska imovina</i>	D. Kratkoročne obveze
<i>IV. Novac u banci i blagajni</i>	E. Odgođeno plaćanje troškova i prihod budućega razdoblja
D. Plaćeni troškovi budućeg razdoblja i obračunati prihodi	F. Ukupno – pasiva
E. Ukupno aktiva	G. Izvanbilančni zapisi
F. Izvanbilančni zapisi	

Izvor: Šodan S.: Financijska analiza poslovanja, skripta, Split, ak.god. 2014./2015. predavanja br. 4 i 5, str. 3.

2.2.2. Račun dobiti i gubitka

Račun dobiti i gubitka pruža informacije o učinkovitosti upotrebe resursa poduzeća, tj. prikazuje prihode, rashode i financijski rezultat poslovanja za određeno razdoblje. Prihodi su definirani kao povećanja ekonomskih koristi kroz obračunsko razdoblje u obliku priljeva ili povećanja sredstava, što ima za posljedicu povećanje imovine i smanjenje obveza, a rashodi predstavljaju smanjenje ekonomske koristi kroz obračunsko razdoblje u obliku odljeva sredstava, što ima za posljedicu smanjenje imovine i povećanja obveza.¹⁵

¹⁵ Žager K., Žager L. (2008): Analiza financijskih izvještaja, op.cit., str. 70. – 71.

U Tablici 3 je prikazan skraćeni oblik računa dobiti i gubitka.

Tablica 3: Temeljne pozicije računa dobiti i gubitka

Poslovni prihodi
Poslovni rashodi
1.Promjene vrijednosti zaliha proizvodnje u tijeku i gotovih proizvoda
2.Materijalni troškovi
3.Troškovi osoblja
4.Amortizacija
5.Ostali troškovi
6.Vrijednosno usklađivanje
7.Rezerviranja
8.Ostali poslovni rashodi
Financijski prihodi
Financijski rashodi
Udio u dobiti od pridruženih poduzetnika
Udio u gubitku od pridruženih poduzetnika
Izvanredni – ostali prihodi
Izvanredni – ostali rashodi
Ukupni prihodi
Ukupni rashodi
Dobit ili gubitak prije oporezivanja
Porez na dobit
Dobit ili gubitak razdoblja

Izvor: Šodan S.: Financijska analiza poslovanja, skripta, Split, ak.god. 2014./2015., predavanja br. 4 i 5, str. 4.

Stavljanjem u odnos prihoda i rashoda ostvarenih u obračunskom razdoblju dobiva se uvid u ostvareni rezultat poslovanja. Naime, ako su prihodi veći od rashoda ostvaren je pozitivan financijski rezultat, tj. dobit. U obrnutom slučaju kad su rashodi veći od prihoda radi se o negativnom financijskom rezultatu, tj. gubitku. Pozitivni financijski rezultat povećava vrijednost kapitala, dok ostvareni gubitak smanjuje vrijednost kapitala.¹⁶

¹⁶ Vujević I. (2009): Analiza financijskih izvještaja, ST-tisak, Split, str. 45

2.2.3. Izvještaj o ostaloj sveobuhvatnoj dobiti

Izvještaj o ostaloj sveobuhvatnoj dobiti prezentira sve komponente dobiti ili gubitka kao i komponente ostale sveobuhvatne dobiti. Prema zahtjevima MRS-a 1, u izvještaj o ostaloj sveobuhvatnoj dobiti treba uključiti ove stavke:¹⁷

1. svaki sastavni dio ostaloga sveobuhvatnog dobitka razvrstan po vrsti, bez iznosa pod 2.)
2. udio u ostaloj sveobuhvatnoj dobiti pridruženih društava i zajedničkih pothvata obračunanih metodom udjela,
3. ukupnu sveobuhvatnu dobit te
4. ukupnu sveobuhvatnu dobit razdoblja pripisanu: vlasnicima manjinskih udjela i vlasnicima matice.

2.2.4. Izvještaj o novčanim tokovima

Izvještaj o novčanim tokovima daje informacije o izvorima i upotrebi gotovine tijekom izvještajnog razdoblja, ali predstavljaju i bazu za planiranje budućih gotovinskih tijekova i potreba za financiranjem.¹⁸ Primici i izdaci novca razvrstavaju se u tri vrste aktivnosti: poslovne, investicijske i financijske. Poslovne aktivnosti su glavne aktivnosti poduzeća koje stvaraju prihod i koje u osnovi imaju najznačajniji utjecaj na financijski rezultat poduzeća, dobit ili gubitak.¹⁹ Investicijske aktivnosti proizlaze iz promjena dugotrajne imovine, javljaju se u svezi investicija i izdataka za nabavku dugotrajnih resursa u cilju stvaranja buduće dobiti i budućih novčanih tokova. Financijske aktivnosti su vezane uz financiranje poslovanja poduzeća, obavljanju transakcija s vlasnicima i kreditorima tvrtke. Uz financijske aktivnosti se vežu promjene strukture obveza i kapitala.

Za izradu izvještaja o novčanim tokovima u MRS-u 7 se navode dvije metode i to:²⁰

1. Direktna metoda izvještavanja (podrazumijeva objavljivanje glavnih skupina bruto novčanih primitaka i izdataka. Direktna metoda pruža informacije koje mogu biti korisne u procjenjivanju budućih novčanih tijekova, a koje nisu raspoložive prema indirektnoj metodi.)

¹⁷ Cirkveni Filipović, T. (2011): Izvještaj o ostalom sveobuhvatnom dobitku, Računovodstvo, revizija i financije, čl. 5, str. 171.

¹⁸ Vidučić Lj. (2006): Financijski menadžment, op.cit., str. 371.

¹⁹ Žager K., Žager L. (1999): Analiza financijskih izvještaja, op.cit., str. 58.

²⁰ Hrvatsko zakonodavstvo: <http://zakon.poslovna.hr/public/mrs-%E2%80%93-2%C2%A0%C2%A0%C2%A0%C2%A0%C2%A0%C2%A0-zalihe/10253/zakoni.aspx> [23.8.2016.]

2. Indirektna metoda izvještavanja (prema kojoj se dobit ili gubitak usklađuje za efekte transakcija nenovčane prirode, svi obračunski iznosi iz prethodnih ili budućih poslovnih novčanih priljeva i odljeva, te za stavke prihoda i rashoda koje su vezane za investicijske ili financijske novčane tokove.)

2.2.5. Izvještaj o promjenama kapitala

Izvještaj o promjeni kapitala prikazuje povećanje ili smanjenje neto imovine za razdoblje između dva datuma bilance. Prema Hrvatskom standardu financijskog izvještavanja 1, izvještaj o promjenama kapitala sadržava promjene uloženog kapitala, zarađenog kapitala i izravne promjene u kapitalu. Svrha izvještaja o promjenama kapitala je dati prikaz promjene neto vrijednosti tvrtke, odnosno bogatstva dioničara, pri čemu se u bilješkama daje uzrok rasta ili eventualnog pada glavnice.²¹ Sastavlja se za određeno obračunsko razdoblje, najčešće za jednu godinu, tj. za isti period kao i ostala financijska izvješća.

2.2.6. Bilješke uz financijske izvještaje

Bilješke uz financijske izvještaje detaljnije obrazlažu informacije sadržane u ostalim temeljnim financijskim izvještajima. Također, u bilješkama se navode i one informacije koje nisu sadržane u ostalim temeljnim financijskim izvještajima. Bilješke nisu formalno određene, njen sadržaj i struktura uvelike ovise o vrsti djelatnosti, organizacijskom obliku poduzeća i zahtjevima korisnika. Sastavljanje i prezentiranje dodatnih informacija u bilješkama doprinosi kvaliteti i razumljivosti računovodstvenih informacija.²²

²¹ Vujević I. (2009): Analiza financijskih izvještaja, op.cit., str. 64.

²² Žager K., Žager L. (2008): Analiza financijskih izvještaja, op.cit., str. 89.

3. TEORIJSKI OSVRT NA PROGNOСТИČKE MODELE PREDVIĐANJA FINANCIJSKIH NESTABILNOSTI

Pojedinačni pokazatelji su nositelji informacija o likvidnosti, zaduženosti, ekonomičnosti, profitabilnosti i investiranju. Da bi se dobila cjelokupna slika o poslovanju, navedene skupine pokazatelja potrebno je promatrati povezano i međuzavisno. Zbog toga su formirani zbrojni ili skupni financijski pokazatelji koji predstavljaju ponderirani zbroj više pokazatelja, te na taj način stavljaju u zavisni odnos nekoliko odabranih pokazatelja koje sintetiziraju cjelinu.²³ Zahvaljujući dugogodišnjem istraživanju i naporu mnogih stručnjaka i znanstvenika danas su poznati različiti modeli skupnih pokazatelja koji su još poznati pod nazivom modeli rizika ili prognostički modeli za predviđanje financijske nestabilnosti poduzeća. Neki od značajnijih modela koji će biti obuhvaćeni ovim radom su: Altmanov Z score model, Kralicekov DF pokazatelj, Zmijewski model, Springate model i BEX indeks.

3.1. Altmanov Z-score model

Edward I. Altman proveo je prvo multivarijatno istraživanje odnosa financijskih pokazatelja i vjerojatnosti za stečaj, čijim je istraživanjem nastao model nazvan Altman Z-score.²⁴ Razvijen je na temelju analize podataka za 66 američkih proizvodnih poduzeća za razdoblje od 1945. do 1965. godine. Pritom su formirane dvije jednake grupe poduzeća: 33 poduzeća koja su bankrotirala i 33 "zdrava" poduzeća. Za potrebe istraživanja izračunata su 22 pokazatelja koja su postupkom multivarijantne diskriminacijske analize reducirana na pet pokazatelja s najvećom diskriminacijskom snagom.²⁵ Diskriminacijska funkcija glasi:

$$Z = 1,2X_1 + 1,4X_2 + 3,3X_3 + 0,6X_4 + 1,0X_5 \quad (1)$$

Tablica 4: Nazivi pokazatelja

Nazivi pokazatelja	Brojnik	Nazivnik
X ₁	radni kapital	ukupna aktiva
X ₂	zadržana dobit	ukupna aktiva
X ₃	operativna dobit	ukupna aktiva
X ₄	tržišna vrijednost glavnice	ukupne obveze
X ₅	prihod od prodaje	ukupna imovina

Izvor: Šodan S.: Financijska analiza poslovanja, skripta, Split, ak.god. 2015./2016., predavanja br. 10, str. 4.

²³ Žager K., Žager L. (2008): Analiza financijskih izvještaja, op.cit., str. 269.

²⁴ Ibidem, str. 270.

²⁵ Šodan S.: Financijska analiza poslovanja, skripta, Split, ak.god. 2015./2016., predavanja br. 10, str. 4.

Objašnjenja svih pet pokazatelja Altman Z-score modela: ²⁶

1. Pokazatelj (X_1) predstavlja omjer radnog kapitala i ukupne imovine, te ja istaknut kao najbolji indikator poslovnih poteškoća. Pokazatelj (X_1) je ujedno i pokazatelj likvidnosti. Poduzeće koje prolazi kroz poslovne poteškoće imat će smanjenje tekuće imovine prema ukupnoj imovini.
2. Pokazatelj (X_2) stavlja u odnos kumulativnu profitabilnost i pokazuje udio reinvestirani sredstava tijekom godine. Također uzima u obzir starost poduzeća, jer se smatra kako je pojava stečaja puno češća u ranim godinama poslovanja poduzeća.
3. Pokazatelj (X_3) prikazuje profitabilnost poduzeća. Budući da je egzistencija poduzeća temeljena na snazi stvaranja dobiti korištenjem imovine, ovaj se pokazatelj čini prikladnim za predviđanje budućeg bankrota.
4. Pokazatelj (X_4) je omjer koji pokazuje koliko može pasti vrijednost imovine prije nego obveze nadmaše veličinu imovine, odnosno prije nego poduzeće postane insolventno.
5. Pokazatelj (X_5) je mjera sposobnosti menadžmenta u uvjetima konkurentnog okruženja. Pokazatelj (X_5) je pokazatelj aktivnosti. Na individualnoj bazi ovaj je pokazatelj najmanje važan.

Kriteriji za odlučivanje su: ukoliko je vrijednost Z-score poduzeća niža od 1,81 ukazuje na financijske poteškoće, tj. veliku opasnost od pokretanja stečajnog postupka, dok vrijednost iznad 2,99 znači da se radi o financijski stabilnom poduzeću. Vrijednost unutar intervala od 1,81 do 2,99 predstavlja tzv. "sivu zonu". ²⁷

Budući da je prvotni model za predviđanje stečaja izveden korištenjem podataka proizvodnih poslovnih subjekata čije su vrijednosnice izlistane na burzi, Altman je u kasnijim istraživanjima izvršio dvije korekcije. Prva se odnosila na prilagodbe modela za predviđanje stečaja onim poslovnim subjektima čije vrijednosnice nisu izlistane na burzi, odnosno koji su u vlasništvu manjeg broja osoba.²⁸ Sukladno tome, u brojniku varijable X_4 došlo je do zamjene tržišne vrijednosti glavnice njezinom knjigovodstvenom vrijednošću, a prilagođeni su i ponderi pa novi model izgleda ovako:

$$Z' = 0,717X_1 + 0,847X_2 + 3,107X_3 + 0,42X_4 + 0,998X_5 \quad (2)$$

²⁶ Šodan S.: Financijska analiza poslovanja, skripta, Split, ak.god. 2015./2016., predavanja br. 10, str. 4.

²⁷ Zenzerović R., Peruško T. (2006): Kratki osvrt na modele za predviđanje stečaja, Ekonomska istraživanja, str. 142.

²⁸ Ibidem

Prilikom tumačenja ovog modela potrebno je obratiti pozornost na nove kritične vrijednosti koje iznose 2,90 i 1,23.

Druga izmjena rezultat je nastojanja da se model prilagodi predviđanju stečaja neproizvodnih poslovnih subjekata. Iz modela je tako isključena varijabla X_5 jer se ona bitno razlikuje između različitih djelatnosti. Izmjenom modela došlo je do izmjene kritičnih vrijednosti koje sada iznose 2,60 i 1,10.²⁹ Druga modifikacija glasi ovako:

$$Z'' = 6,56X_1 + 3,26X_2 + 6,72X_3 + 1,05X_4 \quad (3)$$

3.2. Kralicekov DF pokazatelj

Prilikom ocjene modela treba imati na umu gospodarsko okruženje u kojem poduzeće posluje. Altmanov Z- score model je nastao na uzorku američkih poduzeća, s toga je Kralicek razvio model za prognozu mogućnosti nastanka financijske nestabilnosti koji je prilagođen europskom okruženju.³⁰ Na temelju statičkih i dinamičkih pokazatelja razvijen je sljedeći model:

$$DF = 1,5X_1 + 0,08X_2 + 10X_3 + 5X_4 + 0,3X_5 + 0,1X_6 \quad (4)$$

gdje je:

X_1 = čisti novčani tok (EBIT + amortizacija) / ukupne obveze

X_2 = ukupna imovina / ukupne obveze

X_3 = EBIT / ukupna imovina

X_4 = EBIT / ukupni prihodi

X_5 = zalihe / ukupni prihodi

X_6 = poslovni prihodi / ukupna imovina

²⁹ Zenzerović R., Peruško T. (2006): Kratki osvrt na modele za predviđanje stečaja, op.cit., str. 143.

³⁰ Šodan S.: Financijska analiza poslovanja, skripta, Split, ak.god. 2015./2016., predavanja br. 10, str. 6.

U tablici 5 su navedene kritične veličine na osnovu kojih se može donijeti zaključak o financijskoj stabilnosti poduzeća.

Tablica 5: Kriteriji za odlučivanje

Vrijednosti DF pokazatelja	Financijska stabilnost
>3.0	Izvrсна
>2.2	Vrlo dobra
>1.5	Dobra
>1.0	Osrednja
>0.3	Loša
≤ 0.3	Početak insolventnosti
≤ 0.0	Umjerena insolventnosti
≤ -1.0	Izrazita insolventnost

Izvor: Šodan S.: Financijska analiza poslovanja, skripta, Split, ak. god. 2015./2016., predavanja br. 10, str. 6.

3.3. Zmijewski model

Zmijewski model za predviđanje bankrota razvijen je 1984. godine. U svom izračunu uključuje pokazatelje koji mjere uspješnost poslovanja, zaduženosti i likvidnosti poduzeća. Zmijewski model temelji se na podacima 800 poduzeća koja nisu bankrotirala i 40 poduzeća čije je poslovanje završilo bankrotom, a pri izradi modela korištena je probit analiza.³¹

Multivarijantnom probit analizom dobiven je sljedeći model:³²

$$Y = -4,3 - 4,5X_1 + 5,7X_2 + 0,004X_3 \quad (5)$$

gdje je:

X_1 = neto dobit / ukupna imovina

X_2 = ukupni dug / ukupna imovina

X_3 = kratkotrajna imovina / kratkoročne obveze

Nakon izračuna vrijednosti Y potrebno je izračunati vjerojatnost stečaja na sljedeći način:

$$\text{Vjerojatnost stečaj} = 1 / (1 + \exp(-y)) \quad (6)$$

Ako je dobivena vjerojatnost veća od 0,5, smatra se da poduzeće ima velike šanse za stečaj.

³¹ Šarlija N. (2008): Kreditna analiza, predavanja, Osijek, poglavlje 7, str. 139.

³² Šodan S.: Financijska analiza poslovanja, skripta, Split, ak. god. 2015./2016., predavanja br. 10, str. 5.

3.4. Springate model

Springate model koristi se za predviđanje bankrota. Razvijen je 1978. godine po uzoru na Altmanov model, te je prilagođen kanadskim tržišnim uvjetima. Ovaj model je važan za investitore, kreditore i vlasnike poduzeća jer pruža informacije prijeti li poduzeću bankrot, tj. kolika je mogućnost da poduzeće bankrotira. U početku se smatralo da model procjenjuje financijsko stanje poduzeća sa 92, 5% sigurnošću, ali kasnijim testiranjem ovog modela sigurnost procjene se smanjila te se sad nalazi između 83% i 88%.³³

Springate model glasi:³⁴

$$Z = 1,03X_1 + 3,07X_2 + 0,66X_3 + 0,4X_4 \quad (7)$$

Varijable u modelu su:

X_1 = obrtni kapital / ukupna imovina

X_2 = dobit prije kamata i poreza / ukupna imovina

X_3 = dobit prije poreza / kratkoročne obveze

X_4 = prihodi od prodaje/ ukupna imovina

Ako je rezultat manji od 0,862 znači da postoji velika mogućnost bankrota poduzeća.

3.5.BEX indeks

BEX indeks su formirali Vinko Belak i Željana Aljinović Barać 2007. godine, s ciljem procjene poslovne izvrsnosti poduzeća na tržištu kapitala u Hrvatskoj. Preko BEX indeksa može se izmjeriti trenutna i očekivana poslovna izvrsnost poduzeća. Ovaj model se također može primijeniti i na poduzeća koja ne kotiraju na burzi. BEX indeks je konstruiran u skladu sa uvjetima poslovanja u hrvatskom gospodarstvu.³⁵

BEX model sastoji se od četiri pokazatelja s određenim ponderima utjecaja, što tvori sljedeći izraz:

$$BEX = 0,388 \times ex_1 + 0,579 \times ex_2 + 0,153 \times ex_3 + 0,316 \times ex_4 \quad (8)$$

gdje su obuhvaćena ova područja procjene izvrsnosti s pokazateljima:³⁶

³³ Šarlija N. (2008): Kreditna analiza, predavanja, Osijek, op. cit., str. 139. – 140.

³⁴ Sadgrove K. (2005): The complete guide to business risk management, Gower Publishing, Ltd., 2. izdanje, str. 178.

³⁵ Aljinović Barać Ž.: Računovodstvo novčanih tijekova, predavanja, Split, ak.god. 2009./2010., str. 4.

³⁶ Belak V., Aljinović Barać Ž. (2008): Tajne tržišta kapitala, Belak Excellens d.o.o., Zagreb, str. 34.

ex₁ = PROFITABILNOST

$$ex_1 = \text{EBIT} / \text{ukupna aktiva} \quad (9)$$

ex₂ = STVARANJE VRIJEDNOSTI

$$ex_2 = \text{neto poslovna dobit} / (\text{vlastiti kapital} \times \text{cijena}) \quad (10)$$

ex₃ = LIKVIDNOST

$$ex_3 = \text{radni kapital} / \text{ukupna aktiva} \quad (11)$$

ex₄ = FINANCIJSKA SNAGA

$$ex_4 = 5 \times \text{EBITDA} / \text{ukupne obveze} \quad (12)$$

Pokazatelj ex_1 je izvrsnost mjerena odnosom zarade (koja se sastoji od kamata i dobiti prije poreza) i kapitala mjerenog ukupnom aktivom.

Pokazatelj ex_2 bazira se na ekonomskom profitu – dobiti koja prekoračuje cijenu vlastitoga kapitala. U izračunu se rabi kategorija poslovne dobiti kako bi se izbjegli utjecaji izvanrednih događaja na rezultat poslovanja. Cijena vlastitoga kapitala je izračunata iz umnoška vlasničkog kapitala i cijene kapitala koju bi vlasnici mogli ostvariti iz alternativnih, relativno nerizičnih ulaganja. Pod vlasničkim kapitalom se podrazumijeva upisani kapital, uvećan za eventualne dobitke i rezerve. Ako je ex_2 veći od 1, tvrtka stvara vrijednost, a ako je manji od 1 tvrtka "jede" svoju supstancu.

Za mjerenje likvidnosti rabi se klasičan pokazatelj odnosa radnog kapitala prema ukupnoj aktivi. Radni kapital se izračunava kao razlika između tekuće aktive i tekućih obveza.

Pokazatelj ex_4 temelji se na odnosu teorijski slobodnog novca iz svih aktivnosti što je dobit uvećana za amortizaciju i deprecijaciju i pokriva svih obveza tim novcem. Ovaj pokazatelj nema linearni utjecaj.

U Tablici 6 je prikazana ukupna poslovna izvrsnost BEX indeksa.

Tablica 6: Ukupna poslovna izvrsnost BEX indeksa

Bex indeks	Rang poslovne izvrsnosti
>1,0	Dobre tvrtke
0 - 1	Potrebna su unapređenja
< 0	Ugrožena egzistencija

Izvor: Šodan S.: Financijska analiza poslovanja, skripta, Split, ak.god. 2015./2016., predavanja br. 10, str. 8.

U Tablici 7 je prikazano rangiranje poslovne izvrsnosti i prognoza za budućnost poduzeća.

Tablica 7: Rangiranje poslovne izvrsnosti i prognoza za budućnost

Business excellence indeks (BEX)	Rang poslovne izvrsnosti (Business excellence rang)	Prognoza za budućnost
veći od 6,01 - 4 godine uzastopno	Svjetska klasa (world class)	Tvrtka posluje sa vrhunskim rezultatima što se može očekivati i u iduće 4 godine, ako menadžment nastavi sa unaprjeđenjima.
veći od 6,01	kandidati za svjetsku klasu (world class candidate)	Tvrtka posluje izvrsno što se može očekivati i u sljedeće 3 godine, ako menadžment nastavi sa unaprjeđenjima.
4,01 - 6,00	izvrsno	Tvrtka posluje izvrsno što se može očekivati i u sljedeće 3 godine, ako menadžment nastavi sa unaprjeđenjima.
2,01 - 4,00	vrlo dobro	Tvrtka posluje vrlo dobro što se može očekivati i u sljedeće 2 godine, ako menadžment nastavi sa unaprjeđenjima.
1,01 - 2,00	dobro	Tvrtka posluje dobro, ali se poboljšanje može očekivati samo ako se pristupi unaprjeđenjima.
0,00 - 1,00	ograničeno područje između dobrog i lošeg	Poslovna izvrsnost je pozitivna, ali nije zadovoljavajuća. Potrebno je pristupiti ozbiljnim unaprjeđenjima.
manji od 0,00 (negativan)	loše	Ugrožena je egzistencija. Potrebno je žurno pristupiti restrukturiranju i unaprjeđenjima, inače će se loše poslovanje nastaviti pa postoji opasnost od propasti (vjerojatnost je preko 90%)

Izvor: Belak V., Aljinović Barać Ž. (2008): Tajne tržišta kapitala, Belak Excellens d.o.o., Zagreb, str. 34.

4. ANALIZA MODELA ZA PREDVIĐANJE FINACIJSKE NESTABILNOSTI NA PRIMJERU PROIZVODNIH PODUZEĆA U RH

Ovo poglavlje se odnosi na praktični dio rada. Za praktični dio rada su izabrana četiri poduzeća iz djelatnosti proizvodnje kemikalija i kemijskih proizvoda, a to su redom: Chromos Agro d.d., Petrokemija d.d., Saponia d.d. i Tvornica olovaka Zagreb d.d.. Poduzeća Chromos Agro d.d. i Saponia d.d. danas ostvaruju pozitivne rezultate poslovanja. Poduzeće Petrokemija d.d. se danas suočava sa velikim financijskim poteškoćama i prijeti mu stečaj, dok poduzeće Tvornica olovaka Zagreb d.d. je u stečaju od 2015. godine. Cilj je na temelju raspoloživih financijskih podataka svih navedenih poduzeća izračunati modele za predviđanje financijske nestabilnosti i ustanoviti jesu li modeli precizni ili ne glede ocjene financijskog stanja poduzeća. Također je bitno ustanoviti kada su modeli predviđali mogućnost financijskih problema, tj. koji je model najranije upozorio na stečaj. Analiza prognostičkih modela se provodi za razdoblje od 2011. do 2014. godine.

4.1. Izračun modela za predviđanje financijske nestabilnosti za poduzeće Chromos Agro d.d.

U nastavku će se provesti izračun svih prethodno objašnjenih prognostičkih modela za poduzeće Chromos Agro d.d., te će se na temelju rezultata ustanoviti financijsko stanje poduzeća i prognoze poslovanja poduzeća u narednim godinama. Također će se ustanoviti koji su modeli dali najprecizniju ocjenu tj. prognozu financijskog stanja poduzeća, tako da će se te prognoze usporediti sa današnjom financijskom situacijom poduzeća.

4.1.1. Opći podaci o poslovanju Chromos Agro d.d.

Chromos Agro d.d. je zagrebačko poduzeće koje posluje već 75 godina. Chromos Agro d.d. se bavi proizvodnjom i distribucijom sredstava za zaštitu bilja – pesticida. Godišnji proizvodni kapaciteti iznose oko 25 000 tona različitih proizvoda. Chromos Agro d.d. pokriva oko 50% hrvatskog tržišta, dok veliku količinu proizvoda izvozi u zemlje Europske Unije, Bosnu i Hercegovinu, Makedoniju i Srbiju. Poduzeće danas ima oko 87 zaposlenika.³⁷

³⁷ Chromos Agro d.d.: <http://www.chromos-agro.hr/o-nama/chromos-agro-d-d-danas/> [24.08.2016.]

Chromos Agro je dioničko društvo, temeljni kapital iznosi 36.149.100,00 kn, ukupan broj izdanih dionica je 120.497, nominalni iznos jedne dionice je 300kn. Predsjednik Uprave je Krunoslav Čović, dipl. oec..³⁸

4.1.2. Izračun Altman Z- score modela

U Tablici 8 su prikazani rezultati izračuna Altman Z- score modela za poduzeće Chromos Agro d.d., za razdoblje od 2011. – 2014. godine.


Tablica 8: Izračun Altman Z - score modela

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X ₁	0,506	0,422	0,379	0,283
X ₂	0,475	0,504	0,516	0,500
X ₃	0,026	0,023	0,023	0,019
X ₄	2,253	2,725	2,950	2,624
X ₅	0,447	0,380	0,326	0,302
Z- score	2,237	2,325	2,342	2,091

Izvor: Izrada autora

Altman Z- score model je izračunat na temelju jednadžbe: $Z' = 0,717X_1 + 0,847X_2 + 3,107X_3 + 0,42X_4 + 0,998X_5$, pri čemu je kod pokazatelja X₄ tržišna vrijednost glavnice zamijenjena knjigovodstvenim iznosom poduzeća. Ova je jednadžba korištena iz razloga što nisu dostupni podaci o tržišnoj kapitalizaciji poduzeća. Dobiveni rezultati pokazatelja i u konačnici Altman Z- score modela ukazuju na to da se poduzeće Chromos Agro d.d. nalazi u sivoj zoni poslovanja ($2,90 > Z > 1,23$), tj. da mu je u sva četiri promatrana razdoblja ugrožena financijska stabilnost ali s potencijalnim ozdravljenjem. Što se tiče kretanja pojedinačnih pokazatelja, može se uočiti smanjenje vrijednosti pokazatelja kroz promatrano razdoblje. Najveće smanjenje je zabilježeno kod pokazatelja likvidnosti, razlog tome je pad obrtnog kapitala pri čemu poduzeće gubi sposobnost ulaganja u rast poslovanja. Za kraj se može zaključiti da ovaj model upozorava poduzeće da mu je ugrožena financijska stabilnost, ali i dalje postoji mogućnost ozdravljenja, tj. poboljšanja poslovanja.

³⁸ Chromos Agro d.d.: <http://www.chromos-agro.hr/o-nama/> [24.08.2016.]



Slika 1. Altmanov Z - score model za poduzeće Chromos Agro d.d. (2011. - 2014.)

Izvor: Izrada autora

4.1.3. Izračun Kralicekovog DF pokazatelja


Vrijednosti DF pokazatelja za poduzeće Chromos Agro d.d. su prikazane u Tablici 9.

Tablica 9: Izračun Kralicekovog DF pokazatelja

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X ₁	0,112	0,122	0,130	0,105
X ₂	3,253	3,725	3,950	3,624
X ₃	0,026	0,023	0,023	0,019
X ₄	0,053	0,055	0,063	0,058
X ₅	0,651	0,731	0,836	0,778
X ₆	0,483	0,422	0,355	0,333
DF	1,194	1,251	1,337	1,200

Izvor: Izrada autora

Vrijednosti DF pokazatelja upućuju na to da poduzeće Chromos Agro d.d. posluje osrednje, na granici između dobrog i lošeg poslovanja. Jednako kao i kod izračuna Altman Z-score modela može se uočiti porast vrijednosti pokazatelja u 2013. godini nakon čega slijedi pad vrijednosti pokazatelja u 2014.godini što upućuje na opasnost od mogućeg stečaja ako poduzeće ne unaprijedi poslovanje.



Slika 2. Kralicekov DF pokazatelj za Chromos Agro d.d. (2011. - 2014.)

Izvor: Izrada autora

4.1.4. Izračun Zmijewskog modela


Prikaz izračuna Zmijewskog modela za poduzeće Chromos Agro d.d., za četiri promatrana razdoblja.

Tablica 10: Izračun Zmijewskog modela

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X ₁	0,006	0,006	0,007	0,006
X ₂	0,307	0,268	0,253	0,276
X ₃	3,523	3,066	2,746	2,082
Zmijewski model	-2,559	-2,786	-2,875	-2,746
Vjerojatnost stečaja	0,072	0,058	0,053	0,060


Izvor: Izrada autora

Prema dobivenim rezultatima u Tablici 10 može se zaključiti da poduzeću Chromos Agro d.d. ne prijeti stečaj, jer su vrijednosti dobivene na temelju izračuna vjerojatnosti stečaja manje od 0,5. U odnosu na prethodne modele, izračunom Zmijewskog modela dobiveni su pozitivniji rezultati na temelju kojih se jedino može zaključiti pozitivno poslovanje poduzeća bez naznaka eventualnog stečaja u idućim poslovnim godinama.



Slika 3. Zmijewski model za Chromos Agro d.d. (2011. - 2014.)

Izvor: Izrada autora



Slika 4. Vjerojatnost stečaja za Chromos Agro d.d. (2011. - 2014.)

Izvor: Izrada autora

4.1.5. Izračun Springate modela


Prikaz rezultata Springate modela za poduzeće Chromos Agro d.d., za razdoblje od 2011. do 2014. godine.

Tablica 11: Izračun Springate modela

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X ₁	0,506	0,422	0,379	0,283
X ₂	0,026	0,023	0,023	0,019
X ₃	0,039	0,044	0,041	0,033
X ₄	0,447	0,380	0,326	0,302
Springate model	0,805	0,687	0,617	0,494

Izvor: Izrada autora

Springate model polazi od tvrdnje da ako je dobiveni rezultat manji od 0,862 postoji velika mogućnost za bankrot. Prema rezultatima vidljivim u Tablici 11 može se zaključiti da poduzeću Chromos Agro d.d. prijeti bankrot. Osobito loš rezultat je u 2014. godini, iznosi 0,494 i znatno je ispod prosjeka. Ovaj model se može poistovjetiti sa prethodnim modelima koji također prikazuju 2014. godinu kao godinu lošeg poslovanja nakon koje mogu uslijediti poslovne neprilike za poduzeće, ukoliko poduzeće ne poduzme potrebite akcije za unaprjeđenje poslovanja.



Slika 5. Springate model za Chromos Agro d.d. (2011. - 2014.)

Izvor: Izrada autora

4.1.6. Izračun BEX indeksa

Rezultati pokazatelja BEX indeksa za poduzeće Chromos Agro d.d., koji se odnose na razdoblje od 2011. do 2014. godine prikazani su u Tablici 12.


Tablica 12: Izračun BEX indeksa

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
ex ₁	0,024	0,021	0,019	0,019
ex ₂	0,694	0,581	0,506	0,518
ex ₃	0,518	0,432	0,389	0,290
ex ₄	0,235	0,292	0,335	0,281
Bex indeks	0,565	0,503	0,465	0,441

Izvor: Izrada autora

Kod BEX indeksa je primijenjen drugačiji način izračuna EBIT-a i neto poslovne dobiti u odnosu na prethodne prognostičke modele. EBIT se računa prema formuli: $EBIT = \text{dobit prije oporezivanja} + \text{financijski rashodi} - \text{financijski prihodi}$, dok neto poslovna dobit obuhvaća razliku između poslovnih prihoda i poslovnih rashoda umanjenu za porez na dobit. Cijena vlastitog kapitala je 4%.

Prema Tablici 12, dobiveni rezultati BEX indeksa (od 2011. – 2012. godine) kreću se između ocjena 0 i 1, iz čega proizlazi da su poduzeću Chromos Agro d.d. potrebna unaprjeđenja. Ako se uzme u obzir detaljnije rangiranje poslovne izvrsnosti, poduzeće se nalazi u graničnom području između dobrog i lošeg poslovanja, što znači da je poslovna izvrsnost pozitivna, ali nije zadovoljavajuća. Unatoč ostvarivanju dobiti u sva četiri promatrana razdoblja, potrebno je pristupiti ozbiljnom unaprjeđenju poslovanja. Također se može uočiti uzastopni pad indeksa, tj. poslovne izvrsnosti poduzeća kroz promatrano razdoblje.



Slika 6. BEX indeks za poduzeće Chromos Agro d.d. (2011. - 2014.)

Izvor: Izrada autora

4.2. Izračun modela za predviđanje financijske nestabilnosti za poduzeće Petrokemija d.d.

U nastavku će se provesti izračun prognostičkih modela za poduzeće Petrokemija d.d. te će se na temelju ostvarenih rezultata utvrditi financijska situacija poduzeća. Također će se utvrditi kakav scenarij poslovanja predviđa svaki pojedini model i kolika je njihova preciznost u procjeni.

4.2.1. Opći podaci o poslovanju poduzeća Petrokemija d.d.

Poduzeće Petrokemija d.d. je osnovano 1965. godine. Sjedište poduzeća je u gradu Kutini. Osnovne djelatnosti poduzeća su proizvodnja mineralnih gnojiva i proizvoda od bentonitnih glina i čađe. Prosječno godišnje proizvede oko 1,2 milijuna tona mineralnih gnojiva. Prodajna politika proizvoda na hrvatskom tržištu temelji se na vlastitoj veleprodaji, tj. vrši izravnu prodaju malim poljoprivrednim poduzećima i zadrugama. Osim što svoje proizvode izvozi u zemlje regije (Bosnu i Hercegovinu, Sloveniju, Crnu Goru i Srbiju), također izvozi u zemlje Europske unije (Italiju, Španjolsku, Njemačku, Francusku, Austriju). Petrokemija d.d. zapošljava oko 1639 zaposlenika.³⁹

Temeljni kapital iznosi 386.135.400,00 kuna. Ima 12.871.180. redovnih dionica na službenom tržištu Zagrebačke burze. Dionička struktura je sljedeća: 79,85% Republika Hrvatska, a ostatak investicijski fondovi i privatni investitori.⁴⁰

4.2.2. Izračun Altman Z-score modela

U Tablici 13 prikazani su rezultati Altman Z- score modela. Izračun se proveo na temelju podataka iz financijskih izvještaja poduzeća Petrokemija d.d., za razdoblje od 2011. do 2014. godine.

Tablica 13: Izračun Altman Z - score modela

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X ₁	0,057	-0,027	-0,142	-0,212
X ₂	-0,135	-0,071	0,000	0,000
X ₃	0,090	-0,066	-0,173	-0,189
X ₄	0,731	0,427	0,371	0,261
X ₅	1,598	1,521	1,557	1,392
Z' score	2,109	1,414	1,070	0,761


Izvor: Izrada autora

Rezultati dobiveni izračunom Altman Z-score modela ukazuju na iznimno loše poslovanje poduzeća, osobito od 2012. godine nakon koje slijedi pad financijske stabilnosti poduzeća. Kad se uzmu u obzir pojedinačni pokazatelji ovog modela, mogu se uočiti vrlo niske, pa i negativne vrijednosti pokazatelja likvidnosti i profitabilnosti. Razlog tome leži u sve većim dugovima

³⁹ Petrokemija d.d. : http://www.petrokemija.hr/Portals/0/Petrokemija_HR.pdf [26.08.2016.]

⁴⁰ Petrokemija d.d. : http://www.petrokemija.hr/Portals/0/Petrokemija_HR.pdf [26.08.2016.]

poduzeća koje ne uspijeva podmiriti i uzastopno ostvarivanje negativnog poslovnog rezultata. U konačnici, Altman Z-score model upozorava na negativno poslovanje i mogućnost skorašnjeg stečaja.



Slika 7: Altmanov Z - score model za poduzeće Petrokemija d.d. (2011. - 2014.)

Izvor: Izrada autora

4.2.3. Izračun Kralicekovog DF pokazatelja

Vrijednosti pokazatelja su prikazane u Tablici 14.


Tablica 14: Izračun Kralicekovog DF pokazatelja

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X ₁	0,246	-0,021	-0,157	-0,162
X ₂	1,731	1,427	1,371	1,261
X ₃	0,090	-0,066	-0,173	-0,189
X ₄	0,055	-0,042	-0,108	-0,133
X ₅	0,220	0,217	0,173	0,232
X ₆	1,625	1,555	1,586	1,415
DF	1,916	-0,563	-2,188	-2,483

Izvor: Izrada autora

Prema dobivenim rezultatima iz Tablice 14, Petrokemija d.d. u 2011. godini posluje izvrsno, nakon čega je uslijedio pad u naredne tri godine (2012. – 2014.) Poduzeće u posljednje tri godine je izrazito insolventno zbog porasta obveza, tj. dugovi poduzeća premašuju vrijednost

imovine. Polazno od toga poduzeće ostvaruje uzastopni gubitak poslovanja. Prognoza Kralicekovog DF pokazatelja je skorašnji stečaj poduzeća.



Slika 8. Kralicekov DF pokazatelj za poduzeće Petrokemija d.d. (2011. - 2014.)

Izvor: Izrada autora

4.2.4. Izračun Zmijewskog modela


U Tablici 15 su prikazani rezultati izračuna Zmijewskog modela za poduzeće Petrokemija d.d. u razdoblju od 2011. do 2014. godine.

Tablica 15: Izračun Zmijewskog modela

	Godina			
Pokazatelji	2011.	2012.	2013.	2014.
X_1	0,059	-0,097	-0,204	-0,229
X_2	0,578	0,701	0,729	0,793
X_3	1,108	0,958	0,792	0,727
Y	-1,270	0,135	0,778	1,251
Vjerojatnost stečaja	0,219	0,534	0,685	0,777


Izvor: Izrada autora

Zmijewski model prikazuje rezultate poprilično slične rezultatima izračuna prethodnih modela rizika. Kao i prethodni modeli ukazuje na iznimno dobro poslovanje Petrokemije u 2011. godini, te uzastopni pad u iduće tri godine. Vjerojatnost stečaja se povećala u posljednje tri godine, jer su vrijednosti veće od 0,5, te ovaj model prognozira stečaj poduzeća.



Slika 9. Zmijewski model za poduzeće Petrokemija d.d. (2011. - 2014.)

Izvor: Izrada autora



Slika 10. Vjerojatnost stečaja za poduzeće Petrokemija d.d. (2011. - 2014.)

Izvor: Izrada autora

4.2.5. Izračun Springate modela


Prikaz rezultata Springate modela za poduzeće Petrokemija d.d., za razdoblje od 2011. – 2014. godine.

Tablica 16: Izračun Springate modela

	Godina			
Pokazatelji	2011.	2012.	2013.	2014.
X ₁	0,057	-0,027	-0,142	-0,212
X ₂	0,090	-0,066	-0,173	-0,189
X ₃	0,113	-0,154	-0,299	-0,294
X ₄	1,598	1,521	1,557	1,392
Springate model	1,050	0,278	-0,252	-0,435

Izvor: Izrada autor

Prema rezultatima Springate modela, poduzeće u 2011. godini posluje izvrsno, dok se u naredne tri godine može uočiti pad profitabilnosti i likvidnosti poduzeća. Također je vidljivo da su vrijednosti znatno ispod kritične veličine te ovaj model prognozira skorašnji stečaj poduzeća.



Slika 11. Springate model za poduzeće Petrokemija d.d. (2011. - 2014.)

Izvor: Izrada autora

4.2.6. Izračun BEX indeksa

U Tablici 17 prikazani su rezultati izračuna BEX indeksa za poduzeće Petrokemija u razdoblju od 2011. do 2014. godine.


Tablica 17: Izračun BEX indeksa

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
ex ₁	0,077	-0,079	-0,184	-0,196
ex ₂	3,913	-4,530	-11,676	-16,194
ex ₃	0,057	-0,027	-0,142	-0,212
ex ₄	0,964	-0,326	-0,993	-1,062
Bex indeks	2,609	-2,761	-7,167	-9,820

Izvor: Izrada autora

Nakon 2011. godine slijedi negativan trend poslovanja poduzeća Petrokemija d.d. Vrijednosti pojedinačnih pokazatelja su negativne. Primjerice pokazatelj ex₂ (stvaranje vrijednosti) je ispod 0, što znači da poduzeće "jede svoju supstancu", odnosno nije u mogućnosti reinvestirati i poboljšati svoje poslovanje. Isto tako pokazatelj ex₄ koji predstavlja financijsku snagu

poduzeća je negativan, što znači da je poduzeću ugrožena egzistencija. U konačnici BEX indeks prognozira skorašnji stečaj poduzeća, te je vjerojatnost stečaja veća od 90%.



Slika 12. BEX indeks za poduzeće Petrokemija d.d. (2011. - 2014.)

Izvor: Izrada autora

4.3. Izračun modela za predviđanje financijske nestabilnosti za poduzeće Saponia d.d.

U nastavku su izračunati svi prognostički modeli za poduzeće Saponia d.d. Na temelju rezultata doneseni su zaključci vezani za financijsko stanje poduzeća u promatrana četiri razdoblja te prognoze za nastavak poslovanja.

4.3.1. Opći podaci o poslovanju poduzeća Saponia d.d.

Saponia d.d. je vodeća deterdžentsko- toaletna industrija, sa sjedištem u Osijeku. Posluje već 118 godina. Saponia d.d. proizvodi približno 500 različitih proizvoda. Ima tri osnovne skupine proizvoda: deterdženti široke potrošnje, toaletni program i sredstva za velike potrošače i industriju. Saponia d.d. trenutno broji oko 1000 zaposlenika. Ima pet skladišno – distributivnih centara koji se nalaze u Nemetinu, Zagrebu, Splitu, Rijeci i Dubrovniku. Saponia d.d. svoje proizvode izvozi u Bosnu i Hercegovinu, Srbiju, Crnu Goru, Makedoniju, Sloveniju, Kosovo, Švedsku i Albaniju.⁴¹

Saponia d.d. je uvrštena na kotaciju javnih društava na Zagrebačkoj burzi. Temeljni kapital iznosi 197.569.200 kn te je podijeljen na 658.564 dionice čija je nominalna vrijednost 300.00

⁴¹ Saponia d.d.: <http://www.saponia.hr/korporativno> [26.08.2016.]

kn. Vlasnička struktura je: Mepas d.o.o. Široki Brijeg (87,30%), HFP (0,28%), mali dioničari (11,94%), trezorske dionice (0,48%).⁴²

4.3.2. Izračun Altman Z – score modela

U Tablici 18 su prikazani rezultati izračuna Altman Z- score modela za poduzeće Saponia d.d., za četiri promatrana razdoblja.


Tablica 18: Izračun Altman Z - score modela

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X ₁	0,215	0,221	0,229	0,228
X ₂	0	0	0	0
X ₃	0,031	0,070	0,054	0,050
X ₄	1,032	1,279	1,398	1,500
X ₅	0,904	1,038	1,104	1,091
Z' score	1,585	1,949	2,020	2,037

Izvor: Izrada autora

Na temelju rezultata najlošije poslovanje je zabilježeno u 2011. godini, nakon koje slijedi financijski oporavak. Naime, ako se uzmu u obzir kritične veličine ovog modela može se zaključiti da je poduzeću Saponia d.d. ugrožena financijska stabilnost, ali s potencijalnim ozdravljenjem. Također, vidljiv je porast vrijednosti pokazatelja od 2011. do 2014. godine što ukazuje na stabilizaciju poslovanja i smanjenje vjerojatnosti stečaja. U konačnici Altman Z-score model prognozira poboljšanje poslovanja poduzeća Saponia d.d.

⁴² Saponia d.d.: http://www.saponia.hr/static/pdf/Tromjesecno_izvjesce_za_Q3-2012-konsolidirano.pdf [29.08.2016.]



Slika 13. Altmanov Z - score model za poduzeće Saponia d.d. (2011.- 2014.)

Izvor: Izrada autora

4.3.3. Izračun Kralicekovog DF pokazatelja


Vrijednosti DF pokazatelja su prikazane u Tablici 19.

Tablica 19: Izračun Kralicekovog DF pokazatelja

	Godina			
Pokazatelji	2011.	2012.	2013.	2014.
X ₁	0,109	0,212	0,199	0,209
X ₂	2,032	2,279	2,398	2,500
X ₃	0,031	0,070	0,054	0,050
X ₄	0,033	0,065	0,047	0,045
X ₅	0,104	0,094	0,077	0,076
X ₆	0,919	1,053	1,116	1,099
DF	0,922	1,663	1,398	1,369

Izvor: Izrada autora

Vrijednosti Kralicekovog DF pokazatelja ukazuju na vrlo dobru financijsku stabilnost poduzeća Saponia d.d. U 2011. godini je ostvarena najniža vrijednost, dok u sljedećim godinama slijedi porast vrijednosti DF pokazatelja. Prema ovom pokazatelju poduzeće je izuzetno financijski stabilno te mu ne prijeti stečaj.



Slika 14. Kralicekov DF pokazatelj za poduzeće Saponia d.d. (2011. - 2014.)

Izvor: Izrada autora

4.3.4. Izračun Zmijewskog modela


U nastavku su prikazani rezultati Zmijewskog modela za poduzeće Saponia d.d., u razdoblju od 2011. do 2014. godine.

Tablica 20: Izračun Zmijewskog modela

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X_1	0,012	0,011	0,017	0,034
X_2	0,492	0,439	0,417	0,400
X_3	1,604	1,733	1,780	1,722
Y	-1,543	-1,842	-1,993	-2,168
Vjerojatnost stečaja	0,176	0,137	0,120	0,103

Izvor: Izrada autora

Zmijewski model prognozira financijsku stabilnost poduzeća u narednim godinama. Razlog tome su vrijednosti vjerojatnosti stečaja koje su ispod kritične veličine od 0,5, što se smatra da poduzeću ne prijete stečaj.



Slika 15. Zmijewski model za poduzeće Saponia d.d. (2011.- 2014.)

Izvor: Izrada autora



Slika 16. Vjerojatnost stečaja za poduzeće Saponia d.d. (2011. - 2014.)

Izvor: Izrada autora

4.3.5. Izračun Springate modela


U Tablici 21 su prikazani rezultati Springate modela za poduzeće Saponia d.d., za četiri promatrana razdoblja.

Tablica 21: Izračun Springate modela

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X ₁	0,215	0,221	0,229	0,228
X ₂	0,031	0,070	0,054	0,050
X ₃	0,041	0,044	0,065	0,109
X ₄	0,904	1,038	1,104	1,091
Springate model	0,704	0,887	0,885	0,897

Izvor: Izrada autora

Jednako Zmijewskom modelu i Springate model prognozira pozitivno financijsko stanje za poduzeće Saponia d.d. Vrijednosti ovog modela se uzastopno povećavaju, što umanjuje opasnost od bankrota.



Slika 17. Springate model za poduzeće Saponia d.d. (2011. - 2014.)

Izvor: Izrada autora

4.3.6. Izračun BEX indeksa


U nastavku su prikazani rezultati izračuna BEX indeksa za razdoblje od 2011. do 2014. godine.

Tablica 22: Izračun BEX indeksa

	Godina			
Pokazatelji	2011.	2012.	2013.	2014.
ex ₁	0,014	0,047	0,039	0,038
ex ₂	0,612	1,734	1,341	1,313
ex ₃	0,206	0,217	0,226	0,227
ex ₄	0,357	0,388	0,555	0,850
Bex indeks	0,504	1,178	1,001	1,079

Izvor: Izrada autora

BEX indeks ukazuje na poboljšanje poslovanja i financijske stabilnosti Saponie d.d., od 2011. do 2014. godine. Razlog tome su sve veće vrijednosti BEX indeksa, koje prelaze ocjenu 1 što ukazuje na sve bolje poslovanje poduzeća. Ako se nastavi unaprjeđivanje poslovanja BEX indeks prognozira pozitivno poslovanje poduzeća Saponia d.d. u narednim godinama.



Slika 18. BEX indeks za poduzeće Saponia d.d. (2011. - 2014.)

Izvor: Izrada autora

4.4. Izračun modela za predviđanje financijske nestabilnosti za poduzeće TOZ Penkala d.d.

U nastavku su izračunati svi prognostički modeli za poduzeće TOZ Penkala d.d. Na temelju rezultata doneseni su zaključci vezani za financijsko stanje poduzeća te prognoze nastavka poslovanja.

4.4.1. Opći podaci o poslovanju poduzeća TOZ Penkala d.d.

TOZ Penkala, Tvornica olovaka Zagreb d.d. osnovana je u Zagrebu 1937. godine. Osnovna djelatnost je bila proizvodnja olovaka i pastela, a kasnije proizvodnja školskog i uredskog pribora. TOZ Penkala je polovinu svojih proizvoda izvozila na svjetsko tržište, a zemlje izvoza su bile: Njemačka, Turska, Italija, Makedonija i Bosna i Hercegovina. U zadnjih nekoliko godina imala je oko 50 zaposlenika. Dugogodišnje poslovanje je prekinuto 2015. godine kad je otvoren stečaj nad poduzećem.⁴³

Temeljni kapital društva je iznosio 60.000.000,00 kn i bio je podijeljen na 200.000 dionica na ime u nominalnoj vrijednosti 300,00 kn.⁴⁴

⁴³ TOZ Penkala d.d.: <http://www.toz-penkala.hr/kronika-drustva> [26.08.2016.]

⁴⁴ TOZ Penkala d.d. : <http://www.toz-penkala.hr/osnovni-podaci> [26.08.2016.]

4.4.2. Izračun Altman Z- score modela


Izračun Altman Z- score modela je proveden na temelju podataka iz temeljnih financijskih izvještaja poduzeća TOZ Penkala d.d. i to za razdoblje od 2011. – 2014. godine. Rezultati su prikazani u Tablici 23.

Tablica 23: Izračun Altman Z - score modela

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X ₁	0,055	0,007	0,019	0,012
X ₂	-0,181	-0,185	-0,257	-0,272
X ₃	0,018	-0,061	-0,004	0,002
X ₄	5,147	4,304	3,936	3,941
X ₅	0,157	0,149	0,106	0,106
Z' score	2,260	1,613	1,543	1,546

Izvor: Izrada autora

Prema Altman Z-score modelu poduzeće TOZ Penkala d.d. se nalazi u sivoj zoni poslovanja, tj. ugrožena mu je financijska stabilnost u sva četiri promatrana razdoblja. No, Altman Z- score model i dalje ističe mogućnost potencijalnog ozdravljenja poduzeća, odnosno unaprjeđenja poslovanja u narednim godinama.



Slika 19. Altman Z - score model za poduzeće TOZ Penkala d.d. (2011. - 2014.)

Izvor: Izrada autora

4.4.3. Izračun Kralicekovog DF pokazatelja


Vrijednosti DF pokazatelja su prikazane u Tablici 24.

Tablica 24: Izračun Kralicekovog DF pokazatelja

Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X ₁	0,152	-0,286	0,015	0,044
X ₂	6,147	5,304	4,936	4,941
X ₃	0,018	-0,061	-0,004	0,002
X ₄	0,107	-0,374	-0,035	0,016
X ₅	0,570	0,389	0,730	0,755
X ₆	0,160	0,162	0,109	0,118
DF	1,620	-2,356	0,430	0,800

Izvor: Izrada autora

Kralicekov DF pokazatelj već u 2012. godini prognozira skorašnji stečaj poduzeća. Vrijednosti ovog pokazatelja su iznimno niske te ukazuju na izrazitu insolventnost poduzeća. Kako se može vidjeti u tablici negativan trend poslovanja se nastavio i u narednim godinama.



Slika 20. Kralicekov DF pokazatelj za poduzeće TOZ Penkala d.d. (2011. - 2014.)

Izvor: Izrada autora

4.4.4. Izračun Zmijewskog modela


Prikaz izračuna Zmijewskog modela za poduzeće TOZ Penkala d.d., za četiri promatrana razdoblja.

Tablica 25: Izračun Zmijewskog modela


Pokazatelji	Godina			
	2011.	2012.	2013.	2014.
X ₁	0,006	-0,072	-0,012	-0,006
X ₂	0,163	0,189	0,203	0,202
X ₃	1,499	1,053	1,155	1,092
Y	-3,393	-2,896	-3,086	-3,114
Vjerojatnost stečaja	0,033	0,052	0,044	0,043

Izvor: Izrada autora

Prema dobivenim rezultatima u Tablici 25 vidljivo je da poduzeću TOZ Penkala ni u jednoj promatranoj godini ne prijeti stečaj, jer su vrijednosti dobivene na temelju izračuna vjerojatnosti stečaja manje od 0,5. Za razliku od prethodno izračunati modela, Zmijewski model prikazuje obrnutu sliku poslovanja poduzeća te ne ukazuje na bilo kakvu mogućnost stečaja u skorašnjem razdoblju.

**Slika 21. Zmijewski model za poduzeće TOZ Penkala d.d. (2011. - 2014.)**

Izvor: Izrada autora



Slika 22. Vjerojatnost stečaja za poduzeće TOZ Penkala d.d. (2011. - 2014.)

Izvor: Izrada autora

4.4.5. Izračun Springate modela


Prikaz rezultata Springate modela za poduzeće TOZ Penkala d.d., za razdoblje od 2011. do 2012. godine.

Tablica 26: Izračun Springate modela

	Godina			
Pokazatelji	2011.	2012.	2013.	2014.
X ₁	0,055	0,007	0,019	0,012
X ₂	0,018	-0,061	-0,004	0,002
X ₃	0,051	-0,572	-0,100	-0,049
X ₄	0,157	0,149	0,106	0,106
Springate model	0,208	-0,499	-0,016	0,028

Izvor: Izrada autora

Rezultati Springate modela su značajno ispod kritične veličine (0,862), što znači da je poduzeće nestabilno te da mu prijeti stečaj. Ovaj model je još u 2011. godini upozorio na mogućnost stečaja.



Slika 23. Springate model za poduzeće TOZ Penkala d.d. (2011. - 2014.)

Izvor: Izrada autora

4.4.6. Izračun BEX indeksa


Rezultati pokazatelja BEX indeksa za poduzeće TOZ Penkala d.d., koji se odnose na razdoblje od 2011. do 2014. godine prikazani su u Tablici 27.

Tablica 27: Izračun BEX indeksa

	Godina			
Pokazatelji	2011.	2012.	2013.	2014.
ex ₁	0,026	-0,129	-0,019	-0,005
ex ₂	0,770	-3,733	-0,630	-0,158
ex ₃	0,107	0,014	0,038	0,024
ex ₄	0,397	-0,343	-0,128	0,012
Bex indeks	0,598	-2,318	-0,407	-0,086

Izvor: Izrada autora

BEX indeks prognozira stečaj još u 2012. godini, kada su vrijednosti modela ispod prosjeka, tj. negativne. Prema rezultatima ovog modela financijska nestabilnost poduzeća je vidljiva još u 2012. godini. Promatranjem pojedinačnih pokazatelja može se ustanoviti da razlog financijske nestabilnosti leži u povećanju duga i ostvarivanju uzastopno negativnog poslovnog rezultata, što se odražava na pad likvidnosti i financijske snage poduzeća.



Slika 24. BEX indeks za poduzeće TOZ Penkala d.d. (2011. - 2014.)

Izvor: Izrada autora

4.5. Sinteza rezultata i ocjena validnosti modela za predviđanje financijske nestabilnosti

U Tablici 28. je prikazano kada i koji model predviđa stečaj.

Tablica 28: Rezultati predviđanja stečaja

	Poduzeća															
	Chromos Agro d.d.				Petrokemija d.d.				Saponia d.d.				TOZ Penkala d.d.			
Modeli	2011	2012	2013	2014	2011	2012	2013	2014	2011	2012	2013	2014	2011	2012	2013	2014
Altmanov Z- score model	ne	ne	ne	ne	ne	ne	da	da	ne	ne	ne	ne	ne	ne	ne	ne
BEX indeks	ne	ne	ne	ne	ne	da	da	da	da	ne	ne	ne	ne	da	da	da
Kralicekov DF pokazatelj	ne	ne	ne	da	ne	da	da	da	ne	ne	ne	ne	ne	da	da	da
Zmijewski model	ne	ne	ne	ne	ne	da	da	da	ne	ne	ne	ne	ne	ne	ne	ne
Springate model	ne	ne	ne	da	ne	da	da	da	ne	ne	ne	ne	da	da	da	da

Izvor: Izrada autora

Obrazloženje: DA – model predviđa stečaj, NE – model predviđa nastavak poslovanja.

Kako bi se utvrdilo koji je model najpreciznije i najranije predvidio stečaj, potrebno je navesti koja poduzeća i u kojoj godini su zapala u financijske probleme, a koja nisu. Tako primjerice poduzeća Saponia d.d. i Chromos Agro d.d. nisu zapadali u financijske nestabilnosti u promatranom razdoblju. Poduzeće TOZ Penkala d.d. je u stečaju od 2015. godine, a nad poduzećem Petrokemija d.d. se provodi postupak predstečajne nagodbe.

Za poduzeće Chromos Agro d.d. prognostički modeli su uglavnom dali pozitivne prognoze poslovanja, jedino u 2014. godini Kralicekov DF pokazatelj i Springate model su reagirali na

pad profitabilnosti poduzeća. Kod poduzeća Petrokemija d.d. prognostički modeli su već u 2012. godini upozoravali na stečaj poduzeća, s tim da je Altman Z- score posljednji upozorio na stečaj, odnosno godinu dana kasnije od ostalih modela. Što se tiče poduzeća Saponia d.d. uglavnom su svi modeli suglasni u vezi financijske stabilnosti poduzeća. Kod poduzeća TOZ Penkala d.d. modeli BEX indeks, Kralicekov DF pokazatelj i Springate predviđaju stečaj poduzeća, s tim da se mora istaknuti Springate model koji je najranije upozorio na stečaj poduzeća.

Kad se uzmu u obzir svi prethodno dobiveni rezultati i predviđanja prognostički modela, može se zaključiti da od pet korištenih prognostički modela, Springate model najpreciznije i najranije predviđa financijske probleme. Iako su prognoze svih modela poprilično slične, Springate model se istaknuo jer je najranije od svih modela upozorio na stečaj poduzeća TOZ Penkala d.d.

5. ZAKLJUČAK

Istraživanje financijske nestabilnosti poduzeća aktualno je u svakom razdoblju i za svaku državu. Temeljni pokazatelji koji su prisutni u modelima za predviđanje financijske nestabilnosti, insolventnosti ili stečaja poduzeća su financijski koeficijenti kreirani iz financijskih izvještaja poduzeća.

U ovom radu proveden je izračun i analiza modela za predviđanje financijske nestabilnosti na temelju četiri proizvodna poduzeća, za razdoblje od 2011. do 2014. godine. Radi se o hrvatskim poduzećima iz djelatnosti proizvodnje kemikalija i kemijskih proizvoda, a to su: Chromos Agro d.d., Petrokemija d.d., Saponia d.d. i TOZ Penkala d.d. Modeli za predviđanje koji su korišteni u ovom radu su: Atlmanov Z- score model, BEX indeks, Kralicekov DF pokazatelj, Zmijewski model i Springate model.

Nakon izračuna i analize svih prognostičkih modela ustanovilo se da su predviđanja prognostičkih modela uglavnom jednaka. Tako primjerice za poduzeće Chromos Agro d.d. svi modeli ukazuju na stabilno poslovanje poduzeća, zatim za poduzeće Saponia d.d. kod kojeg su svi modeli ukazali na dobro poslovanje i financijsku stabilnost poduzeća, kod poduzeća Petrokemija d.d. i TOZ Penkala modeli upozoravaju na loše poslovanje i predviđaju skorašnji stečaj.

Kad se uzmu u obzir svi prethodno dobiveni rezultati, objašnjenja i predviđanja prognostičkih modela može se zaključiti da Springate model najpreciznije i najranije predviđa financijske probleme poduzeća, naime Springate model je najranije upozorio na stečaj poduzeća TOZ Penkala d.d.

Upotrebom modela predviđanja u redovnom poslovanju, njihovim izračunom i analizom, svaki menadžer može pratiti poslovanje svog poduzeća. Također, na temelju modela predviđanja mogu se uvidjeti određeni problemi u poduzeću koje treba na vrijeme sanirati kako ne bi došlo do većih financijskih poteškoća i stečaja.

LITERATURA

Knjige:

1. Belak V., Aljinović Barać Ž. (2008): Tajne tržišta kapitala, Belak Excellens d.o.o., Zagreb
2. Sadgrove K. (2005): The complete guide to business risk management, Gower Publishing, Ltd.
3. Skupina autora (2008): Primjena hrvatskih standarda financijskog izvještavanja, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb
4. Vidučić Lj. (2006): Financijski menadžment, RRiF – plus, d.o.o. za nakladništvo i poslovne usluge, Zagreb
5. Vujević I. (2009): Analiza financijskih izvještaja, ST-tisak, Split
6. Žager K., Žager L. (2008): Analiza financijskih izvještaja, Masmedia, Zagreb
7. Žager K., Žager L. (1999): Analiza financijskih izvještaja, Masmedia, Zagreb

Pravilnik/ zakoni:

1. Zakon o računovodstvu, pročišćeni tekst (NN 78/15, 134/15)

Članci:

1. Cirkveni Filipović, T. (2011): Izvještaj o ostalom sveobuhvatnom dobitku, Računovodstvo, revizija i financije, čl. 5, str. 171.
2. Zenzerović R., Peruško T. (2006): Kratki osvrt na modele za predviđanje stečaja, Ekonomska istraživanja, str. 132-151.

Nastavni materijal:

1. Aljinović Barać Ž.: Računovodstvo novčanih tijekova, predavanja, Split, ak.god. 2009./2010.
2. Šarlija N. (2008): Kreditna analiza, predavanja, Osijek, poglavlje 7.
3. Šodan S.: Financijska analiza poslovanja, skripta, Split, ak.god. 2014./2015. predavanja br. 4

Izvori s interneta:

1. Chromos Agro d.d.: <http://www.chromos-agro.hr/o-nama/chromos-agro-d-d-danas/> [24.08.2016.]
2. Chromos Agro d.d.: <http://www.chromos-agro.hr/o-nama/> [24.08.2016.]
3. Hrvatsko zakonodavstvo: <http://zakon.poslovna.hr/public/mrs-%E2%80%93-2%C2%A0%C2%A0%C2%A0%C2%A0%C2%A0%C2%A0%C2%A0-zalihe/10253/zakoni.aspx> [23.8.2016.]
4. Petrokemija d.d. : http://www.petrokemija.hr/Portals/0/Petrokemija_HR.pdf [26.08.2016.]
5. Petrokemija d.d. : http://www.petrokemija.hr/Portals/0/Petrokemija_HR.pdf [26.08.2016.]
6. Saponia d.d.: <http://www.saponia.hr/korporativno> [26.08.2016.]
7. Saponia d.d.: http://www.saponia.hr/_static_/pdf/Tromjesecno_izvjesce_za_Q3-2012-konsolidirano.pdf
8. TOZ Penkala d.d.: <http://www.toz-penkala.hr/kronika-drustva> [26.08.2016.]
9. TOZ Penkala d.d. : <http://www.toz-penkala.hr/osnovni-podaci> [26.08.2016.]

POPIS TABLICA

Tablica 1: Pokazatelji za razvrstavanje poduzeća prema Zakonu o računovodstvu	6
Tablica 2: Temeljne pozicije bilance - obrazac GFI - POD	9
Tablica 3: Temeljne pozicije računa dobiti i gubitka	10
Tablica 4: Nazivi pokazatelja	13
Tablica 5: Kriteriji za odlučivanje.....	16
Tablica 6: Ukupna poslovna izvrsnost BEX indeksa	18
Tablica 7: Rangiranje poslovne izvrsnosti i prognoza za budućnost	19
Tablica 8: Izračun Altman Z - score modela.....	21
Tablica 9: Izračun Kralicekovog DF pokazatelja.....	22
Tablica 10: Izračun Zmijewskog modela	23
Tablica 11: Izračun Springate modela.....	24
Tablica 12: Izračun BEX indeksa.....	25
Tablica 13: Izračun Altman Z - score modela.....	27
Tablica 14: Izračun Kralicekovog DF pokazatelja.....	28
Tablica 15: Izračun Zmijewskog modela	29
Tablica 16: Izračun Springate modela.....	30
Tablica 17: Izračun BEX indeksa.....	31
Tablica 18: Izračun Altman Z - score modela.....	33
Tablica 19: Izračun Kralicekovog DF pokazatelja.....	34
Tablica 20: Izračun Zmijewskog modela	35
Tablica 21: Izračun Springate modela.....	36
Tablica 22: Izračun BEX indeksa.....	37
Tablica 23: Izračun Altman Z - score modela.....	39
Tablica 24: Izračun Kralicekovog DF pokazatelja.....	40
Tablica 25: Izračun Zmijewskog modela	41
Tablica 26: Izračun Springate modela.....	42
Tablica 27: Izračun BEX indeksa.....	43
Tablica 28: Rezultati predviđanja stečaja.....	44

POPIS SLIKA

Slika 1. Altmanov Z - score model za poduzeće Chromos Agro d.d. (2011. - 2014.).....	22
Slika 2. Kralicekov DF pokazatelj za Chromos Agro d.d. (2011. - 2014.).....	23
Slika 3. Zmijewski model za Chromos Agro d.d. (2011. - 2014.)	24
Slika 4. Vjerojatnost stečaja za Chromos Agro d.d. (2011. - 2014.).....	24
Slika 5. Springate model za Chromos Agro d.d. (2011. - 2014.).....	25
Slika 6. BEX indeks za poduzeće Chromos Agro d.d. (2011. - 2014.).....	26
Slika 7: Altmanov Z - score model za poduzeće Petrokemija d.d. (2011. - 2014.)	28
Slika 8. Kralicekov DF pokazatelj za poduzeće Petrokemija d.d. (2011. - 2014.)	29
Slika 9. Zmijewski model za poduzeće Petrokemija d.d. (2011. - 2014.).....	30
Slika 10. Vjerojatnost stečaja za poduzeće Petrokemija d.d. (2011. - 2014.)	30
Slika 11. Springate model za poduzeće Petrokemija d.d. (2011. - 2014.)	31
Slika 12. BEX indeks za poduzeće Petrokemija d.d. (2011. - 2014.)	32
Slika 13. Altmanov Z - score model za poduzeće Saponia d.d. (2011.- 2014.).....	34
Slika 14. Kralicekov DF pokazatelj za poduzeće Saponia d.d. (2011. - 2014.).....	35
Slika 15. Zmijewski model za poduzeće Saponia d.d. (2011.- 2014.)	36
Slika 16. Vjerojatnost stečaja za poduzeće Saponia d.d. (2011. - 2014.).....	36
Slika 17. Springate model za poduzeće Saponia d.d. (2011. - 2014.).....	37
Slika 18. BEX indeks za poduzeće Saponia d.d. (2011. - 2014.).....	38
Slika 19. Altman Z - score model za poduzeće TOZ Penkala d.d. (2011. - 2014.)	39
Slika 20. Kralicekov DF pokazatelj za poduzeće TOZ Penkala d.d. (2011. - 2014.)	40
Slika 21. Zmijewski model za poduzeće TOZ Penkala d.d. (2011. - 2014.)	41
Slika 22. Vjerojatnost stečaja za poduzeće TOZ Penkala d.d. (2011. - 2014.).....	42
Slika 23. Springate model za poduzeće TOZ Penkala d.d. (2011. - 2014.)	43
Slika 24. BEX indeks za poduzeće TOZ Penkala d.d. (2011. - 2014.)	44

SAŽETAK

U ovom radu, primjenom modela za predviđanje financijske nestabilnosti su dobiveni rezultati na temelju kojih se procjenjivala financijska stabilnost i vjerojatnost stečaja poduzeća. Za izračun i analizu modela korišteni su podaci iz temeljnih financijskih izvještaja četiri hrvatska poduzeća. Radi se o poduzećima iz djelatnosti proizvodnje kemikalija i kemijskih proizvoda. Analiza se provodila za razdoblje od 2011. do 2014. godine. Nakon provedene analize utvrđeno je da je Springate model najpouzdaniji model za predviđanje financijskog neuspjeha poduzeća.

SUMMARY

In this paper, applying the model to predict the financial instability is the results obtained on the basis of which it assessed the financial stability and bankruptcy of enterprises. For the calculation and analysis of the model using the data onto the basic financial statements four Croatian companies. These are the companies engaged in manufacture of chemical products. The analysis was carried out for the period from 2011. to 2014. After the analysis it was found that the Springate model is most reliable model for predicting financial distress.